



Conference: Interdisciplinary Congress of Renewable Energies, Industrial Maintenance, Mechatronics
and Information Technology
BOOKLET



RENIECYT - LATINDEX - Research Gate - DULCINEA - CLASE - Sudoc - HISPANA - SHERPA UNIVERSIA - E-Revistas - Google Scholar
DOI - REDIB - Mendeley - DIALNET - ROAD - ORCID

Title: Detección de anomalías en redes de sensores inalámbricos
Technology and Innovation

Authors: VADILLO-MEJÍA, C., MOO-MENA, F. y GÓMEZ-MONTALVO, J.

Editorial label ECORFAN: 607-8695

BCIERMMI Control Number: 2019-036

BCIERMMI Classification (2019): 241019-036

Pages: 12

RNA: 03-2010-032610115700-14

ECORFAN-México, S.C.

143 – 50 Itzopan Street
La Florida, Ecatepec Municipality
Mexico State, 55120 Zipcode
Phone: +52 1 55 6159 2296
Skype: ecorfan-mexico.s.c.
E-mail: contacto@ecorfan.org
Facebook: ECORFAN-México S. C.

Twitter: @EcorfanC

www.ecorfan.org

Holdings

| | | |
|---------|-------------|------------|
| Mexico | Colombia | Guatemala |
| Bolivia | Cameroon | Democratic |
| Spain | El Salvador | Republic |
| Ecuador | Taiwan | of Congo |
| Peru | Paraguay | Nicaragua |

Introducción

Detección de Anomalías


Métodos de detección de anomalías

Conclusiones

Referencias

Introducción

- ❑ Redes de sensores inalámbricos (WSN).
- ❑ Monitoreo ambiental, monitoreo médico, vigilancia inteligente, y recientemente, en la creación de vehículos autónomos.
- ❑ Sus limitaciones físicas los hace propensos a varios tipos de fallas.
 - ❑ Poder de procesamiento limitado.
 - ❑ Alto costo de comunicación.
 - ❑ Alcance limitado de comunicación directa.




Objetivo

- ❑ El objetivo de este artículo es la introducción a las técnicas de detección de anomalías en redes de sensores inalámbricos.
- ❑ Se hizo una recopilación actualizada de las técnicas más utilizadas, además de una recopilaciones de trabajos que las implementan.
- ❑ Se hizo una clasificación basada en las características de los datos recopilados por la red de sensores inalámbrico.

Detección de anomalías

- ❑ Una anomalía es una observación que es inconsistente con el resto de las muestras observadas.
- ❑ La detección de anomalías consiste en encontrar patrones o datos que no encajen con el comportamiento esperado.
- ❑ En WSN, se desea el uso mínimo de los recursos disponibles.



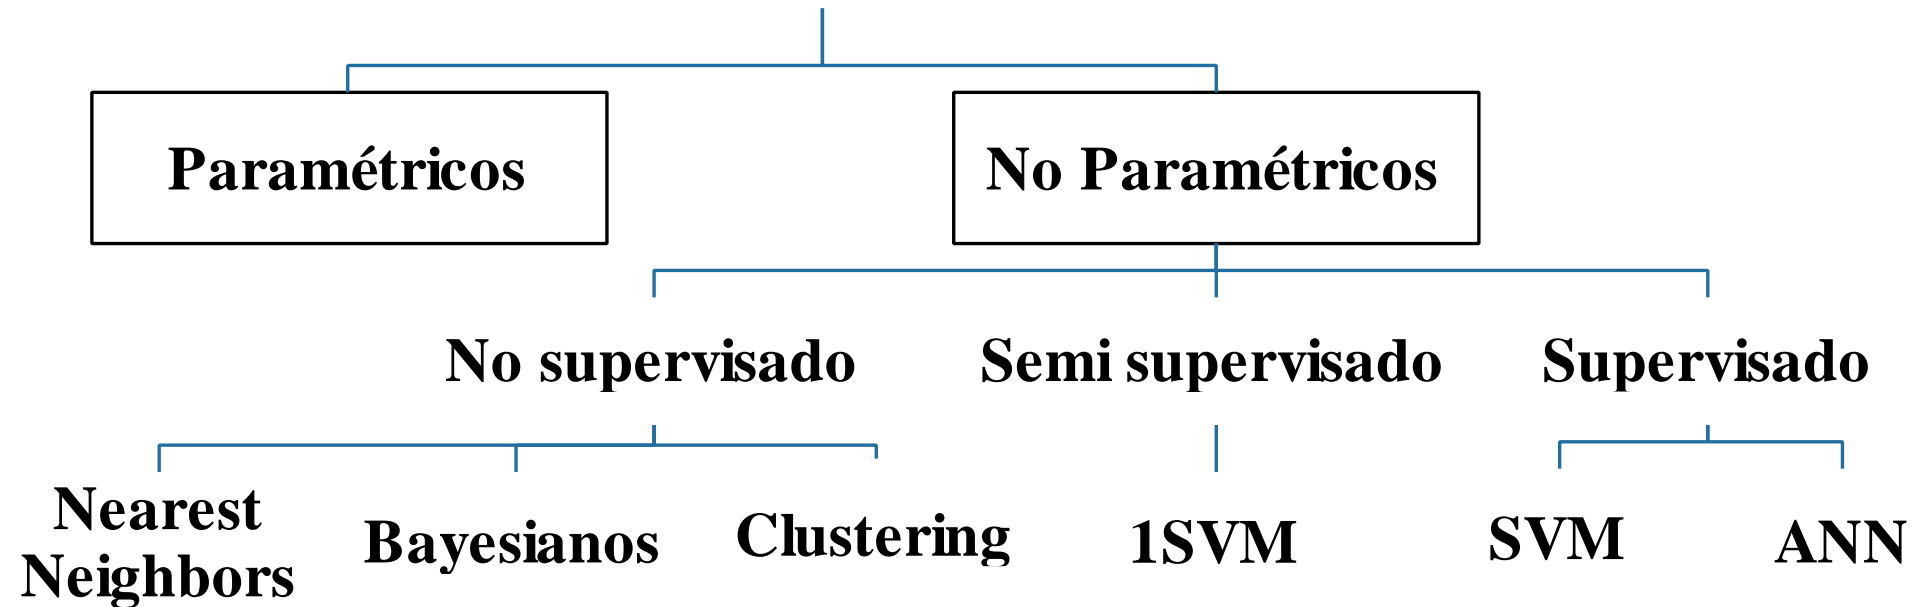
Fuente: Anomaly Detection: Industrial Asset Insights Without Historical Data

Tipos de anomalías en WSN

- Factores que hacen a las WSN ser propensas a la aparición de datos atípicos.
 - Errores de calibración o instalación.
 - Falta de mantenimiento.
 - Cambios en el ambiente.
- Tipos de anomalías:
 - Anomalía puntual.
 - Anomalía contextual.
 - Anomalía colectiva.

Métodos de detección de anomalías en WSN

Detección de Anomalías en WSN



Características

| Categoría | Características |
|-----------------------|--|
| Paramétrico | <ul style="list-style-type: none"> Distribución estadística. Requiere conocimiento a priori del modelo. Entorno estático. Detección rápida. |
| No paramétrico | <ul style="list-style-type: none"> Datos etiquetados. No requiere conocimiento a priori. Más flexibles. Entorno dinámico. Detección moderada/lento. |

| Método | Conocimiento previo | Ventajas | Desventajas |
|-------------------------|---------------------|---|--|
| Supervisado | Si | -Detección rápida de anomalías. | -Requiere datos etiquetados. -Entornos estáticos. -Propenso a sobre entrenamiento. |
| No supervisado | No | -No requiere datos reales de entrenamiento. -Entorno dinámico. | -Detección moderada/lenta. |
| Semi supervisado | Parcial | -Puede aprender progresivamente a medida que los datos estén disponibles. -Flexible a cambios en los datos. -Detección rápida/moderada. | -Si el aprendizaje falla, los errores pueden reforzarse a sí mismos. |

Técnicas no paramétricas

| Categoría | Técnica | Características | Categoría | Técnica | Características |
|------------------|-------------|--|----------------|--------------------------|---|
| Supervisado | <i>SVM</i> | <ul style="list-style-type: none"> Requiere datos etiquetados. Alta complejidad computacional. Buen desempeño en conjuntos de datos pequeños. Usa kernels para lidiar con altas dimensiones. | No supervisado | <i>Clustering</i> | <ul style="list-style-type: none"> No requiere datos etiquetados Consumo elevado de energía Fácil de implementar. Crea agrupaciones de elementos con las mismas características |
| | <i>ANN</i> | <ul style="list-style-type: none"> Requiere datos etiquetados. Robustos y adaptables. capacidad de aprender y modelar relaciones no lineales y complejas. | | <i>Nearest Neighbors</i> | <ul style="list-style-type: none"> No requiere datos etiquetados Consumo elevado de energía Intuitivo y simple No requiere entrenamiento Utiliza la distancia como medida de similitud entre los datos |
| Semi supervisado | <i>ISVM</i> | <ul style="list-style-type: none"> Requiere mínimos datos etiquetados. Útil cuando se tiene poca información de las anomalías | | <i>Bayesiano</i> | <ul style="list-style-type: none"> No requiere datos etiquetados Detectan anomalías a través de probabilidades |

Conclusiones

- ❑ Los métodos paramétricos son adecuados en entornos estables donde la distribución de datos es bien conocida y es poco probable que cambie con frecuencia.
- ❑ Por otro lado, los métodos no paramétricos pueden utilizarse en entornos dinámicos, en los que la distribución estadística es desconocida, pero inferida a través de los datos.
- ❑ Los métodos no paramétricos se pueden subclasificar en otros tres, supervisado, semi supervisado y no supervisado.
- ❑ Los métodos supervisados requieren tener datos de estados normales y anormales.
- ❑ Los semi supervisados aprenden una generalización breve y posteriormente se retroalimentan a medida que los datos estén disponibles.
- ❑ Los no supervisados, como Clustering y basados en Nearest Neighbors, no requiere datos etiquetados.

Conclusiones

- ❑ La elección de una técnica dependerá del problema y el contexto del mismo. Aunque no debemos descartar totalmente el uso de otros métodos a través de modificaciones o mezclas entre ellos.

Acknowledgements

Los autores expresan su agradecimiento al Consejo Nacional de Ciencia y Tecnología de México (CONACYT) por financiar este trabajo a través del Programa de Maestría en Ciencias de la Computación de la Universidad Autónoma de Yucatán.

REFERENCIAS

Anomaly Detection: Industrial Asset Insights Without Historical Data

Anomaly Detection: Industrial Asset Insights Without Historical Data.

(2019). *Engineering.com*. Retrieved 30 September 2019, from

<https://www.engineering.com/AdvancedManufacturing/ArticleID/19058/Anomaly-Detection-Industrial-Asset-Insights-Without-Historical-Data.aspx>



ECORFAN®

© ECORFAN-Mexico, S.C.

No part of this document covered by the Federal Copyright Law may be reproduced, transmitted or used in any form or medium, whether graphic, electronic or mechanical, including but not limited to the following: Citations in articles and comments Bibliographical, compilation of radio or electronic journalistic data. For the effects of articles 13, 162,163 fraction I, 164 fraction I, 168, 169,209 fraction III and other relative of the Federal Law of Copyright. Violations: Be forced to prosecute under Mexican copyright law. The use of general descriptive names, registered names, trademarks, in this publication do not imply, uniformly in the absence of a specific statement, that such names are exempt from the relevant protector in laws and regulations of Mexico and therefore free for General use of the international scientific community. BCIERMMI is part of the media of ECORFAN-Mexico, S.C., E: 94-443.F: 008- (www.ecorfan.org/ booklets)